

智能前沿

群智能优化算法及应用

李煜 刘景森 何小锋 著



 中国经济出版社
CHINA ECONOMIC PUBLISHING HOUSE

智能前沿 群智能优化算法及应用

李煜 刘景森 何小锋 著



 中国经济出版社
CHINA ECONOMIC PUBLISHING HOUSE

· 北京 ·

图书在版编目 (CIP) 数据

智能前沿：群智能优化算法及应用/李煜，刘景森，何小锋著.

—北京：中国经济出版社，2020.5

ISBN 978-7-5136-5869-0

I. ①智… II. ①李… ②刘… ③何… III. ①最优化算法 IV. ①O242.23

中国版本图书馆 CIP 数据核字 (2019) 第 188670 号

组稿编辑 崔姜薇

责任编辑 夏军城

责任印制 马小宾

封面设计 任燕飞

出版发行 中国经济出版社

印刷者 北京九州迅驰传媒文化有限公司

经销者 各地新华书店

开本 710mm×1000mm 1/16

印张 14.75

字数 227千字

版次 2020年5月第1版

印次 2020年5月第1次

定价 58.00元

广告经营许可证 京西工商广字第 8179 号

中国经济出版社 网址 www.economyph.com 社址 北京市东城区安定门外大街 58 号 邮编 100011

本版图书如存在印装质量问题，请与本社销售中心联系调换（联系电话：010-57512564）

版权所有 盗版必究（举报电话：010-57512600）

国家版权局反盗版举报中心（举报电话：12390） 服务热线：010-57512564

目录

CONTENTS

第1章 绪论	001
1.1 引言	003
1.2 群智能优化算法模式综述	007
1.2.1 粒子群优化算法	009
1.2.2 蚁群优化算法	011
1.2.3 量子算法	012
1.2.4 蝙蝠算法	013
1.2.5 人工蜂群算法	014
1.2.6 细菌觅食优化算法	015
1.2.7 萤火虫优化算法	016
1.2.8 布谷鸟优化算法	017
1.2.9 人工鱼群算法	018
1.2.10 混合蛙跳算法	021
参考文献	023
第2章 蝙蝠算法	037
2.1 蝙蝠算法	039
2.1.1 算法的生物学背景	040
2.1.2 算法的基本概念	041
2.1.3 算法流程及进化方程	042
2.2 蝙蝠算法的研究进展	045
2.2.1 蝙蝠算法的提出和改进	045

2.2.2	蝙蝠算法的应用	047
2.2.3	蝙蝠算法研究展望	051
2.3	改进的蝙蝠算法	052
2.3.1	连续优化问题的蝙蝠算法	052
2.3.2	一种动态调整惯性权重的自适应蝙蝠算法	060
2.3.3	融合均匀变异与高斯变异的蝙蝠优化算法	073
2.3.4	混合蝙蝠算法	089
	参考文献	095
第3章	布谷鸟算法	103
3.1	布谷鸟算法基本思想	105
3.2	具有随机惯性权重的布谷鸟算法 (WCS)	107
3.2.1	动态惯性权重	112
3.2.2	惯性权重取值范围研究	114
3.2.3	改进布谷鸟算法的时间复杂度和收敛性分析	115
3.3	种群大小对惯性权重选取的影响	117
3.4	仿真实验	118
3.4.1	WCS 算法与 CS 算法的比较	118
3.4.2	改进算法 (WCS) 与其他算法的对比实验	125
	参考文献	127
第4章	量子算法	135
4.1	量子组合算法研究现状及发展	137
4.1.1	量子遗传算法	138
4.1.2	量子退火算法	139
4.1.3	量子聚类算法	139
4.1.4	量子神经网络	140
4.1.5	量子微粒群算法	140
4.2	群智能优化算法基本原理及其算法步骤	141
4.2.1	引言	141
4.2.2	群智能优化算法基本原理及其算法步骤	141

4.3 量子计算基本原理	149
4.3.1 量子比特	149
4.3.2 量子逻辑门	150
4.3.3 基本量子算法	152
参考文献	154
第5章 量子蚁群优化算法	159
5.1 量子蚁群算法基本思想	161
5.2 量子蚁群算法基本步骤	162
5.3 求解 0-1 背包的量子蚁群算法	162
5.3.1 问题描述	162
5.3.2 信息素表示	163
5.3.3 信息素更新	164
5.3.4 求解 0-1 背包问题的 QACA 算法步骤	164
5.3.5 数值实验	165
5.4 车辆路径问题的量子蚁群算法	167
5.4.1 问题描述	167
5.4.2 车辆路径问题中的量子比特及量子旋转门表述	168
5.4.3 状态转移规则	169
5.4.4 信息素的更新	170
5.4.5 车辆路径问题的量子蚁群算法步骤	171
5.4.6 数据实验及分析	172
5.5 带时间窗的车辆路径问题的量子蚁群算法	174
5.5.1 问题描述	174
5.5.2 带时间窗车辆路径问题中的量子比特及量子旋转门表述	176
5.5.3 状态转移规则	177
5.5.4 信息素的更新	178
5.5.5 带时间窗车辆路径问题的量子蚁群算法步骤	179
5.5.6 时间复杂性分析	180
5.5.7 数据实验及分析	180

5.6	Steiner 最小树问题的量子蚁群算法	185
5.6.1	问题描述	185
5.6.2	Steiner 最小树问题的量子比特及量子旋转门表述	186
5.6.3	状态转移规则	187
5.6.4	信息素的更新	188
5.6.5	s 点的搜索	189
5.6.6	利用 Grover 量子算法构造最小生成树	189
5.6.7	算法步骤	191
5.6.8	时间复杂度分析	192
5.6.9	数值实验	192
5.7	求解图着色问题的量子蚁群算法	194
5.7.1	问题描述	194
5.7.2	信息素更新	196
5.7.3	图着色问题的 QACA 算法设计	196
5.7.4	算法步骤	198
5.7.5	时间复杂度分析	198
5.7.6	数值实验	199
5.8	求解 QoS 组播路由问题的量子蚁群算法	203
5.8.1	问题描述	203
5.8.2	QoS 问题求解中的量子比特和量子逻辑门	206
5.8.3	状态转移规则	207
5.8.4	信息素的更新	208
5.8.5	量子信息素转换	209
5.8.6	算法步骤	209
5.8.7	时间复杂度分析	210
5.8.8	收敛性分析	210
5.8.9	数值实验	212
	参考文献	219
	重要术语索引	227

智能前沿：群智能优化算法及应用

Frontiers in Artificial Intelligence: Swarm Intelligence

Optimization Algorithms and Applications

第 1 章

绪 论

1.1 引言

20世纪60年代以来,智能优化作为一门新兴的交叉学科,从无到有,由弱到强。智能优化的出发点是模拟自然以实现对复杂问题的求解,目前已成为系统科学、计算机科学、人工智能最活跃的研究领域之一,吸引世界范围众多学者的关注和深入研究。^[1-3]越来越多的人致力于研究自然界中存在的计算模式,先后从不同研究视角通过模拟不同的自然现象从而获得更好、更有效的算法。智能算法是研究复杂的、不确定的、变化的环境中智能行为的自适应机制,包括学习能力、对新情况的适应能力、抽象能力、泛化能力、发现能力与联想能力等。智能算法具有很强的多学科交叉特点,它是生物学、神经科学、认知科学、计算机科学、免疫学、哲学、社会性、数学、信息科学、非线性科学、工程学、音乐、物理学等众多学科相互交叉融合的结果,是人们对自然智能认识和模拟的最新成果,它的深入发展将极大地改变人们认识自然、求解现实问题的能力和水平。在工程技术、社会经济以及科学计算领域存在大量复杂的计算问题,这些问题表现出高度的非线性、不可导、不连续、高复杂性。科学家通过模拟自然界的许多现象,如生物的演变进化、生物群体行为、DNA、文化、量子行为等,试图解决自然或人造系统中的各类复杂优化问题,并取得了很大进展。^[2,4,5]

最优化问题分为连续变量问题和离散变量问题两大类,其中,连续变量问题又可称为函数优化问题,一般是求一组实数,或者是一个函数,分

为线性规划和非线性规划两类；离散变量问题一般是从一个无限集或可数无限集里寻找一个对象（如一个整数、一个集合、一个排列或者一个图），往往被称为组合优化问题（Combinatorial Optimization）。^[3,6-9] 在现实生活中，很多问题表现为离散的组合优化问题，例如，旅行商问题是解决商人如何安排经过城市的顺序以使其所走的路程最短；车辆路径问题是解决物流系统如何引导车辆寻路以使其所花代价最小；背包问题是解决旅行者如何在有限的承受能力范围内选择价值最大的物品；最小树问题可以解决现实中的管道铺设、电路设计、通信系统、计算机网络等问题；图着色问题的应用背景包括任务调度、资源分配、排课表、VLSI 布线和测试等，大量的科技、管理及工业设计也可归结为图着色问题来解决。^[10-18] 经过数学家们多年研究和整理，以上这一类组合优化问题被确定为 NP（Non-deterministic Polynomial time，非确定性多项式时间）难题。

在过去的 50 多年中，以遗传算法等为代表的启发式随机搜索算法，在理论和应用方面都取得了长足进步。智能算法的快速发展与其广阔的应用背景紧密相关，随着经济、社会和科学的不断发展，现实中面临的重大问题越来越多，复杂程度也越来越高。为了提高算法的性能必须不断加强对智能计算工作机理的认识，从根本上解决这一问题。^[19] 智能优化没有严格的定义，从不同的角度可以给出不同的定义，其本质主要是利用自然现象构造计算模型，或是利用计算机重现自然现象，具有模拟自然界的特点，一般是一类具有自适应、自组织、自学习能力的模型和算法，可以解决传统优化方法难以解决的各种复杂问题。智能算法的特征是比喻性地使用自然系统潜在的概念、原理和机制，如遗传算法使用生物进化论的复制、变异、杂交等概念和机制。其主要研究领域包括遗传算法^[20-23]、神经网络^[24,25]、粒子群算法^[26,27]、蚁群算法^[28-30]、量子计算^[31-33]、模拟退火^[34,35]、DNA 计算^[36,37]、元胞自动机^[38,39]、布谷鸟算法^[40,41]、膜计算^[42,43]等。

智能优化作为一个新兴的交叉学科领域，自 20 世纪后半叶以来，无论是在理论探索还是应用拓展方面，均得到了全面快速发展，已经成为系统科学、计算机科学、人工智能等领域的一个重要分支。针对经济和社会等

工程技术和管理工作中的重大决策任务,以及科学研究中大量存在的复杂计算任务,智能优化无论是在面向这些任务的复杂系统建模与模拟,还是在复杂决策分析和优化问题的求解方面,均提出了一套崭新的研究思想和解决方案。与传统理论和方法相比,智能优化算法有着强大的全局搜索能力、问题域的独立性、信息处理的隐并行性、应用的鲁棒性和操作的简明性,成为一种具有良好普世性和规模化的优化方法。进入21世纪以来,更是掀起智能算法的研究高潮,短短十年间,新的智能算法竞相涌现,各种算法百花齐放,如和声搜索算法^[44,45]、蝙蝠算法^[46,47]、布谷鸟算法^[41,48]、萤火虫算法^[49,50]等。

传统优化算法为优化问题的求解提供了巨大帮助,但计算过程中也暴露出了一些缺点,^[51]主要表现在以下几个方面:①传统优化算法通常都是从一个初始点出发,每次迭代过程中仅对一个点进行计算,这种算法架构很难发挥现代计算机高速计算的性能,尤其是高性能多处理器的计算机和现代并行计算模式往往很难应用到传统优化算法中,限制了算法求解大规模问题的能力和计算速度。②传统优化算法一般都要求目标函数是连续可微的,甚至有时要求是高阶可微的,但是在实际问题中这样的条件往往很难满足,限制了传统优化算法的应用范围。③传统优化算法在每一次迭代时都要求迭代向改进方向移动,即每一次都要求目标函数值有所降低,这样算法就不会具有“爬山”能力。若算法陷入某个局部的低谷,则无法继续搜索该区域之外的任何其他区域,因此,算法就失去了全局搜索能力。④每种传统优化算法只能求解一部分问题,即算法只能求解符合其适用条件的问题。要应用某种传统优化算法就必须简化甚至改变原有的问题,使之能满足该方法的使用条件。如果问题不满足任何已知的传统优化算法的适用条件,那么用传统优化算法就无法有效求解。^[19,20]

考虑传统优化算法的不足,人们希望能够设计出新的有效的优化方法。特别是20世纪90年代以来,实际问题的结构越来越复杂,规模越来越大,不可微、非线性、不确定性、多目标已经成为这些问题的基本特征,而建立在解析基础上的传统优化算法往往对这些问题的求解无能为力。因此,人们逐渐意识到,必须探索新的优化方法来解决这些问题。同

时随着计算机科学与技术的飞速发展，并渗透各个领域，从根本上改变了人们的工作和生活。如何充分发挥计算机技术的优势推动优化方法的发展，成为人们越来越关注的问题。

智能优化算法的发展得益于运筹学、生物学、物理学、计算数学、计算机科学、人工智能和控制论等学科，充分吸收了这些学科的思想、概念和方法。智能优化算法大都具备自组织性、正反馈性、鲁棒性、并行性和实现简单等特征，为在没有集中控制且不提供全局信息的条件下寻找复杂问题的求解方案提供了思路，为优化问题的求解开辟了新的手段。^[52-54]应用智能优化算法求解优化问题时，其搜索过程通常具有以下一些特征：①个体都具有执行简单的空间或时间上评估和计算能力。②当环境（包括其他个体）发生变化时，个体能够对变化做出响应，特别是出现值得付出代价的改变机会时，个体必须能够改变其行为模式。③不同的个体对环境中的某一变化所表现出的响应行为应该具备多样性。^[22,55,56]

和传统优化算法相比，智能优化算法具有其特有的优化特点：①非单点操作，采用群体搜索策略。智能优化算法大都采用由多个个体组成的群体对可行解空间进行搜索，搜索过程中能够实现对各个体所提供信息的共享。信息的传播可以避免对一些不必要区域的搜索，既能提高算法的搜索效率，又能在一定程度上避免陷入局部极值。②智能优化算法在求解优化问题时，目标函数和约束函数可以不必是解析的，更不必是连续和可微的。智能优化算法可有效求解那些目标函数没有明确表达式，或有表达式但不可精确估值的优化问题。此外，智能优化算法对计算中数据的不确定性有较强的适应能力。③智能优化算法是对自然现象和自然规律的模拟，这些现象和规律所蕴含的深刻的优化思想为算法的设计提供了坚实的科学基础。算法中，个体行为虽然简单但通过个体之间的相互作用，整个群体涌现出智能行为，而这种行为可用于求解优化问题。④智能优化算法不依赖于优化问题本身的数学性质和所求问题本身的结构特征以及其他辅助信息，算法可以用于求解不同类型的优化问题，具有广泛的适用性。^[2,3]

大自然经过亿万年继承创造演化，完美展现了其高效和神奇。人们从自然系统中学到许多知识，并用这些知识发展新的算法和模型来求解复杂

问题。正是模仿生物的智能行为并借鉴其智能机理，许多解决复杂问题的新方法不断涌现。通过对自然智能的建模，我们取得了许多成果从而创建出许多智能系统，随着人们对大自然的进一步观察和研究，又提出了很多有代表性的智能优化算法。每种智能算法都对应一种实际的启发源，例如，DNA^[36]计算是基于诺贝尔生理学或医学奖获得者 Watson 和 Crick 提出的双螺旋结构和诺贝尔化学奖获得者 Mullis 提出的聚合酶链反应；人工蜂群算法^[57]是基于诺贝尔生理学或医学奖获得者 Frisch 破译的蜜蜂跳舞行为；而人工免疫算法^[58]是基于诺贝尔生理学或医学奖获得者 K. Jerne 提出的免疫网络理论。智能优化算法奇妙的思路和广阔的应用领域吸引了大量研究人员不断创新。截至目前，还没有找到一种方法能够应用到所有的优化问题中，为了解决我们所面临的问题，必须研究新的优化算法。

1.2 群智能优化算法模式综述

群智能 (Swarm Intelligence) 优化算法研究是当前智能优化领域的一个研究热点，且已成为交叉学科中一个非常活跃的前沿性研究方向，其已经渗透到各个领域。作为一种新兴的智能优化技术，群智能研究形成于 20 世纪 90 年代。^[29,30,59] 1999 年，Bonabeau、Dorigo 和 Theraulaz 在他们的著作 *Swarm Intelligence: From natural to artificial systems* 中对群智能进行了详细论述和分析，给出了群智能的一种不严格定义，即任何一种由昆虫群体或其他动物社会行为机制而激发设计出的算法，或分布式解决问题的策略均属于群智能。在随后的研究中，Bonabeau 又将群智能详细阐述为无智能或简单智能的主体通过任何形式的聚集协同而表现出智能行为的特性。它是一组简单的智能体集体智能的涌现，这里关心的不是个体之间的竞争，而是它们之间的协作。生物群体中的个体之间遵循聚集、分工、避碰、趋同等协作模式，从而涌现出群体智能。^[19]

J. Kennedy 和 Russell C. Eberhart 在 2001 年出版的专著 *Swarm Intelligence*，可以认为是群智能发展的一个重要里程碑，书中通过观察鸟群

的协同运动，开创了微粒群算法这一群智能方法研究的新领域。*Swarm Intelligence* 的基本观点是，人的智能源于社会交往，文化和认知是人类社交的结果，这一观点成为群智能发展的基石。群智能的思路在没有集中控制，且不提供全局模型的前提下，为寻找复杂的分布式问题求解方案提供了基础。群智能研究在系统复杂性和 NP 问题等方面为人工智能、认知科学等领域的基础理论问题开辟了新的研究途径，也为组合优化、知识发现等实际复杂工程问题提供了新的解决方法。对群智能的探索极大地丰富了智能算法领域的研究。^[60]

1994 年，Mark Millonas 提出了构建一个群体智能系统所应满足的五条基本原则^[61]：

(1) 接近性原则 (proximity principle)：群内个体具有执行简单的时间或空间上的评估和计算的能力。

(2) 优质性原则 (quality principle)：群内个体能对环境包括群内其他个体的关键性因素的变化做出响应。

(3) 多样性反应原则 (principle of diverse response)：群内不同个体对环境中的某一变化所表现出的响应行为具有多样性。

(4) 稳定性原则 (stability principle)：群体的行为模式不会随环境的变化而导致整个的改变。

(5) 适应性原则 (adaptability principle)：环境所发生的变化中，若出现群体值得付出代价的改变机遇，群体必须能够改变其行为模式。

群智能方法自提出以来，已广泛应用于人工智能、通信网络和工业生产等领域。已有大量的群智能方法应用相关的文章发表于国内外各类学术刊物上，大量的文献已经证明群智能方法能够解决不同领域的许多问题。群智能方法可用于解决许多传统方法无法解决的 NP 问题，为许多前瞻性研究提供了新的思路。^[62]

群智能方法易于实现，算法中仅涉及各种基本的数学操作，其数据处理过程对 CPU 和内存的要求也不高，而且这种方法只需要目标函数的输出值，而无须其梯度信息。已完成的群智能理论和应用方法研究证明，群智能方法是一种能够有效解决大多数全局优化问题的新方法，更为重要的

是, 群智能潜在的并行性和分布式梯度为处理大量的以数据库形式存在的数据提供了技术保证。无论从理论研究还是应用研究的角度分析, 群智能理论及其应用研究都具有重要学术意义和现实价值。

下面依次对以下典型的群智能优化算法进行介绍: 粒子群算法^[26,27,63]、蚁群算法^[28-30,60,64]、量子算法^[65,66]、蝙蝠算法^[46,47,67]、蜂群算法^[57,68]、细菌觅食算法^[69]、萤火虫算法^[70]、布谷鸟算法^[41,48]、人工鱼群算法^[71-73]以及混合蛙跳算法^[74-76]等。这些算法一方面优化原理各不相同, 另一方面具有许多相同的特征, 对不同智能优化算法的理解对另一种算法的研究有着重要的启发作用。

1.2.1 粒子群优化算法

微粒群优化算法, 或称为粒子群算法, 是一种模拟鸟群社会行为规律而提出的群体智能优化方法。微粒群算法最早在 1995 年由 Eberhart 和 Kennedy 共同提出,^[26,37,63] 最初意图主要是模拟鸟群的优雅且不可预测的行为, 以发现统御鸟群同步飞行的模式, 以及在最优形式重组时突然改变方向的模式。Eberhart 和 Kennedy 在 1995 年的 IEEE International Conference on Neural Networks 和 6th International Symposium on Micromachine and Human Science 上分别发表了论文 *Particle Swarm Optimization* 和 *A New Optimizer Using Particle swarm Theory*, 标志着微粒群算法的诞生。这个算法简单有效, 易于实现, 适合科学研究和工程应用, 受到越来越多研究者的重视。

在粒子群算法中, 个体, 也叫作粒子, 在超维空间中飞行。在搜索空间内粒子位置的改变是基于个体模仿其他粒子的成功的社会心理倾向, 群内粒子的改变因此受其邻居的经验或知识影响, 一个粒子的搜索行为也因此受群中其他粒子的影响。对此社会行为的建模就是搜索过程中粒子随机地返回之前搜索过程中发现的搜索空间中的成功区域。粒子群中的个体有一个基本的行为, 即仿效邻域个体的成功和他们自己的成功。这个基本行为显现出来的集体行为就是在一个高维搜索空间中发现最优区域。一个 PSO 算法维护一群粒子, 其中每个粒子表示一个潜在的解。粒子在一个多维搜索空间中飞行, 而每个粒子的位置根据它自身的经验及其邻居的经验来调整。驱动优化过程

的是速度向量，速度向量反映了粒子的经验知识和粒子的邻域的社会交换信息。粒子的经验知识通常叫作认知部分，它与粒子离它从开始找到过的最佳位置的距离成正比。社会交换信息叫作速度方程的社会部分。^[77]

生物群体内个体之间的相互作用产生的群体智能，往往能够给某些问题的求解提供有效的方法。鸟群在寻找食物的过程中，个体之间存在信息交流和共享，每个成员可以从其他成员的搜索经验中获益，并调整自身的搜索行为。当不可预测食物源分布状态时，这种个体之间的协作所产生的优势是巨大的。基于信息交流和共享的个体间的协作正是微粒群算法进行优化搜索的基础。在微粒群算法中，将优化问题的搜索空间类比作鸟类的飞行空间，并将每只鸟抽象为一个没有质量的微粒，微粒的位置表示问题的候选解，所需要找到的最优解相当于要搜索的食物。微粒群算法还为每个微粒设置了类似于鸟类运动行为的简化规则，从而能够使整个微粒群的运动表现出和鸟类觅食类似的特征，进而可以用于解决优化问题。

基本微粒群算法的具体实现步骤如下：

步骤 1：随机初始化群体中各微粒的位置和速度。

步骤 2：评价群体中所有微粒的适应度值。

步骤 3：对每个微粒，将其当前适应值和其个体历史最优位置所对应的适应值进行比较。如果当前的适应值更优，那么利用当前位置更新其历史最优位置。

步骤 4：对每个微粒，将其历史最优适应值和群体内或其邻域内所经过的最好位置的适应值进行比较；若更好，则将其作为当前群体内或其邻域内的最优位置。

步骤 5：更新每个微粒的速度和位置。

步骤 6：若没有达到终止条件，则转步骤 2。

目前，微粒群算法已经被广泛用于函数优化、神经网络训练、组合优化、模糊系统控制等领域。^[78-83] 算法比较有潜力的应用领域包括多目标优化、系统设计、模式识别、车间作业调度、机器人路径规划、时频分析和图像处理等。^[84-88]